

DOI:10.3876/j.issn.1000-1980.2026.02.005

基于多模型神经网络的径流缺失数据重建

管亚硕^{1,2}, 连炎清^{1,2}, 金君良^{1,2}, 张佳鹏^{1,2}, 任玉玲^{1,2}

(1. 河海大学长江保护与绿色发展研究院; 2. 河海大学水灾害防御全国重点实验室)

摘要: 针对径流数据缺失问题, 构建了基于多个回归模型的长短期记忆(LSTM)神经网络和反向传播(BP)神经网络相结合的日径流预测模型(MM-LSTM-BP 模型), 该模型采用回归模型提取径流线性、非线性、时序性、随机性特征, 使用 LSTM 神经网络、BP 神经网络串联回归模拟日径流过程。渭河流域实例验证结果表明: MM-LSTM-BP 模型在验证期表现总体优于单一回归方法, 日径流数据的均方根误差(RMSE)降低 50% 以上, 纳什效率系数(NSE)提升到 0.935; MM-LSTM-BP 模型在平水期和退水期的稳定性更好, 与单一回归方法相比, 洪水期洪峰模拟误差减少 6% 以上。

关键词: 径流回归; 深度学习; LSTM 神经网络; BP 神经网络; 渭河流域

Reconstruction of missing runoff data based on multi-model neural networks

Guan Yashuo^{1,2}, Lian Yanqing^{1,2}, Jin Junliang^{1,2}, Zhang Jiapeng^{1,2}, Ren Yuling^{1,2}

(1. Yangtze Institute for Conservation and Development, Hohai University;

2. State Key Laboratory of Water Disaster Prevention, Hohai University)

Abstract: To address the problem of missing runoff data, a daily runoff prediction model (MM-LSTM-BP model) combining a long short-term memory (LSTM) neural network and a back propagation (BP) neural network based on multiple regression models was constructed. In this model, regression models were adopted to extract the linear, nonlinear, temporal, and random characteristics of runoff, and the LSTM neural network and the BP neural network were used in series for the regression simulation of the daily runoff process. The case verification results of the Weihe River Basin indicate that the MM-LSTM-BP model generally performs better than the single regression methods during the verification period; the root mean square error (RMSE) of the daily runoff data decreases by more than 50%, and the Nash efficiency coefficient (NSE) increases to 0.935; the MM-LSTM-BP model has better stability during the normal flow period and the recession period, and the simulation error of the flood peak is reduced by more than 6% during the flood period.

Key words: runoff regression; deep learning; LSTM neural network; BP neural network; the Weihe River Basin

随着水文监测技术的发展, 水文数据在水资源管理、洪水预警以及环境评估等方面发挥了重要作用^[1]。然而, 由于自然条件、监测设备维护或数据采集问题, 部分水文站点存在径流数据缺失或不完整的情况^[2]。缺失数据的存在不仅会降低水文模型的模拟精度与预测能力, 也对水资源的科学管理与决策制定构成严峻挑战。

水文研究中, 面对缺失数据或复杂的水文过程, 一般采用回归模型利用已知的相关变量(如气象数据、径流数据等)建立变量之间的函数关系, 补充或预测缺失数据。例如: 王文卓等^[3]利用嵌套主成分层次贝叶斯回归模型重建了黄河源区的历史降水与汛期径流量的回归关系; 钟加星等^[4]利用多元线性回归、随机森林回归以及 LightGBM 模型对复杂水库调度规则进行了提取, 结果表明 LightGBM 模型对规则的提取具有一定的指导意义; 刘娣等^[5]使用支持向量机、BP 神经网络和随机森林法对土壤湿度进行了反演。与传统多元回归方法相比, 深度学习在物理机制不明确的问题中具有显著优势^[6], 可以从大量数据集中挖掘出复杂的特征。而长短期记忆(LSTM)神经网络作为一种特别的递归神经网络, 可以处理时序相关的水文大数据, 在水文领域得到了广泛应用^[7]。例如: 田焘等^[8]评估了 LSTM 神经网络及其变体模型对湘江流域径流短期预报的性能, 并进行了可解释性分析; 苑希民等^[9]通过 LSTM-GM 神经网络充分挖掘风暴潮增水的时序特征, 提高了风暴潮的预报精度; 石卓等^[10]在 LSTM 神经网络的基础上, 利用径流模数和参数移植法对无资料流

基金项目: 科技部重点研发计划项目(2021YFC3201100); 陕西省科技厅重点研发项目(2020KWZ-023)

作者简介: 管亚硕(2001—), 男, 硕士研究生, 主要从事水文水资源研究。E-mail: 231301010011@hhu.edu.cn

通信作者: 连炎清(1962—), 男, 教授, 博士, 主要从事地下水与水文水资源模拟研究。E-mail: ylian@illinois.edu

域进行了径流模拟;李锐峰等^[11]利用 LSTM 神经网络还原了天然流量序列,揭示了永安溪河流的水文健康;徐嘉远等^[12]利用耦合的 TVGM-LSTM 模型对白河流域进行径流模拟,较好地模拟了汛期和非汛期洪峰;刘莉等^[13]构建的实时校正 ERRIS-LSTM 模型有效提升了雅鲁藏布江流域和椒江流域径流预报可靠性。

单一的多元回归模型都各有侧重^[14],因此本文构建了基于多个回归模型的 LSTM 神经网络和反向传播 (BP) 神经网络相结合的日径流预测模型 (MM-LSTM-BP 模型),探讨 MM-LSTM-BP 模型在缺失径流数据情况下的适用性及准确性,以期为缺失径流数据的重建提供新手段。

1 研究方法

1.1 多元回归方法

岭回归与套索回归均为多元线性回归中处理多重共线性问题的有效方法。二者通过在损失函数中引入回归系数的正则化项,实现对系数的约束与收缩,从而提升模型稳健性,降低过拟合风险。

随机森林多元回归是一种基于决策树的集成学习方法,通过构建多个决策树并根据预测结果提高预测的精度和鲁棒性。随机森林多元回归采用 Bootstrap 有放回随机抽样,以增强数据的随机性,抑制单棵决策树的过拟合,从而提升模型整体泛化能力。

梯度提升回归 (gradient boosting regression, GBR) 是一种强大的集成学习方法,它的核心思想是通过逐步减少模型的残差来提升性能,在之前模型的残差上训练新的弱学习器,使得 GBR 在处理非线性关系时表现出色。

多层感知机回归 (multilayer perceptron, MLP) 是一种基于人工神经网络的回归方法,可以处理复杂的非线性数据关系。MLP 由多个感知器组成,每个感知器是一个基本的神经元,整个网络由输入层、隐藏层以及输出层构成。

贝叶斯回归是将贝叶斯统计应用到回归分析中,与传统的最小二乘法不同,贝叶斯通过引入先验分布和后验分布估计回归系数,可以很好地处理不确定性。先验分布是指在没有观察数据之前,对模型参数的主观认知。后验分布是根据观察到的数据和先验分布更新后的参数分布。贝叶斯方法不仅给出回归系数的估计值,还能提供估计的置信区间,从而反映了参数估计的不确定性。

ARIMAX (auto regressive integrated moving average with exogenous variables) 是 ARIMA 模型的拓展版本,它引入了外生变量使模型可以同时考虑时间序列的自相关性以及外生因素的相关性。AR 为自回归部分,表示的是当前的值是之前值的线性组合;I 为差分部分,通过差分操作使得时间序列平稳;MA 为滑动平均部分,表示当前的值是之前误差项的线性组合;X 代表了外生变量,解释时间序列无法体现的变化^[15]。

1.2 LSTM 神经网络

LSTM 神经网络是递归神经网络 (RNN) 的一种改进形式,通过使用记忆单元解决长时间序列回归时出现的梯度消失问题,使其能够捕捉到时间依赖的特征。LSTM 神经网络中每个单元可以根据输入动态记忆或遗忘信息,因此在预测基于时间的连续变量时非常有效^[16]。LSTM 神经网络的结构由输入层、LSTM 层、全连接层、输出层构成,其中网络核心部分 LSTM 层由遗忘门、输入门、记忆单元以及输出门构成。

1.3 BP 神经网络

BP 神经网络是一种按误差反向传播算法训练的多层前馈神经网络,是目前应用最广泛的神经网络模型之一。它通过信号的正向传播与误差的反向调节两个过程,不断调整网络的连接权重,从而使模型的预测输出逼近期望输出。

1.4 MM-LSTM-BP 模型构建

本文构建的 MM-LSTM-BP 模型结构如图 1 所示,图中 $X_m (m=1,2,\cdots,L)$ 为输入数据, L 为维度个数, $C_{j,m} (j=1,2;m=1,2,\cdots,L-1)$ 为细胞状态, $H_{j,m} (j=1,2;m=1,2,\cdots,L)$ 为隐状态, $Q_i (i=1,2,\cdots,M)$ 为 BP 层的输出, M 为 BP 层神经元个数。构建模型的主要步骤如下:①基于部分样本数据,开展多元回归模型的构建与拟合,其中岭回归、套索回归因在高维数据回归中表现良好,因此用于提取因变量之间的线性关系,随机森林回归、GBR 用于提取因变量之间的非线性关系,多层感知回归则都可以获取,贝叶斯回归可以获取因变量之间的随机性关系,ARIMAX 可以提取因变量之间的时间序列关系;②利用构建的多元回归方法对剩余数据进行径流特征提取;③将多个多元回归方法提取的径流特征作为因变量输入到后续的 LSTM-BP 神经网络中,

为避免过拟合,需去除用于拟合多元回归模型的数据,然后将剩余数据集按照 8 : 2 的比例划分为训练集、验证集用于 MM-LSTM-BP 模型的构建率定工作;④利用构建的 MM-LSTM-BP 模型实现对缺失数据的重建。加入多回归方法特征提取的 MM-LSTM-BP 模型与单一的 LSTM-BP 模型相比,输入变量维度更高,既可以提取径流数据的若干特征,也可以避免过拟合。




图1 MM-LSTM-BP 模型结构
Fig. 1 Structure of MM-LSTM-BP model

1.5 MM-LSTM-BP 模型超参数确定

除了自动率定参数外,构建 MM-LSTM-BP 模型之前有一些超参数需要提前确定,这些超参数会决定训练率定的效率、过拟合、准确度等。本文将 LSTM 神经网络设置为双隐层,并使用 dropout 正则化技术,随机丢弃部分神经元防止模型过拟合,从而提高模型的泛化能力,dropout 参数设置为 0.2,BP 神经网络神经元设置为 6 个;在训练方面,使用自适应估计矩优化算法,学习率为 0.005,最大迭代次数为 500 次,目标函数使用均方根误差。其他超参数的选择如下。

1.5.1 批量大小

批量大小是深度学习中一个重要的超参数,它指的是每一次迭代中输入到模型中的样本大小。在模型训练过程中,批量大小对训练速度、稳定性和最终的泛化能力具有关键作用。较小的批量大小会导致模型更新频繁,训练速度降低,从而增加训练时间;而较大的批量大小则可能容易陷入局部最优,降低模型的泛化能力,导致过拟合^[17],因此选择合适的批量大小非常重要。

本文选择了批量大小分别为 8、16、32、64、128、256 进行分析。由图 2 可知,较大的批量相较于较小的训练速度更快,训练结果更好,但是过大的批量大小训练速度较慢,容易陷入局部最优,优化结果相对不稳定。因此,综合考虑后选用 128 的批量大小进行训练和优化。这一选择不仅能提高训练效率,还能确保模型的稳定性。




图 2 批量大小对训练结果及训练速度的影响

Fig. 2 Effect of batch size on training results and training speed

1.5.2 时间步长

对于 LSTM 神经网络,时间步长是另一个重要的超参数,它指的是在序列输入中,用作模型学习的时间片段。选择合适的时间步长对于模型的性能、预测能力都至关重要^[18]。因此本文通过计算输入变量与相关变量的不同时间步的相关系数来决定时间步长。由图 3 可知(图中咸阳站径流量为实测值,其他为各回归方法计算得到的径流量),各个相关变量在偏移 20 d 左右之后相关系数跌至 0.3 以下(低于 0.3 则不相关),因此时间步定为 20 d。

1.5.3 神经元个数

每一层的神经元个数决定了模型的复杂度。较少的神经元可以避免过拟合,但可能会导致欠拟合;较多的神经元适合更加复杂的数据集,但会带来过拟合的风险。NSE 可以反映训练效果,标准差则可以反映训练的稳定性以及是否出现过拟合现象。由图 4 可知,训练集中随着神经元个数的增加,训练拟合效果呈现变好趋势,但同时训练集出现了不稳定现象。为在训练效果与稳定性之间取得平衡,避免过拟合,本文选择的神经元个数为 24。




图 3 临潼站径流偏移与输入变量之间相关系数

Fig. 3 Correlation coefficient between Lintong runoff offset and input variables




图 4 神经元个数对训练集、验证集训练效果及稳定性的影响

Fig. 4 Effect of number of neurons on training effects and stability of training set and verification set

2 实例验证

2.1 研究区概况与研究数据

选取渭河流域咸阳水文站以下,临潼水文站以上的部分作为研究区域,流域面积 3 430 km²,流域概况如图 5 所示。该流域东南高西北低,海拔 300~2 400 m,位于温带季风区,年降水量 500~690 mm,汛期主要集中在 6—9 月,冬季降水较少,具有明显的季节性降水特征。临潼水文站年均径流量约为 68.7 亿 m³,主要为上游咸阳水文站、支流桃园水文站来水以及流域产流。

本文日径流数据来自黄河水文年鉴,其中黄河流域渭河支流咸阳水文站包括 1961—1971 年、1974 年、

1977—2003 年、2005—2019 年共 54 a 逐日径流数据,临潼水文站包括 1961—1971 年、1974 年、1977—1985 年、2001—2003 年、2005—2019 年共 39 a 日径流数据。与咸阳水文站相比,临潼水文站额外缺失 1986—2000 年的数据,是本文需要重建的径流数据。另外,桃园水文站数据缺失严重,因此在构建回归模型时并不考虑。

CN05.1 数据在黄河流域有较好的适用性^[19],因此本文气象数据选用 CN05.1 数据。CN05.1 数据是由吴佳等^[20]使用国家气象信息中心 2 400 余个国家级台站采用薄盘样条函数法和角距权重方法插值叠加后得到的空间分辨率为 0.25°×0.25°的逐日气象数据,变量包括降水量、日均气温、最高及最低气温、湿度、蒸散发量、风速、日照时长。

多元回归方法中,将咸阳水文站日径流数据及 CN05.1 数据提供的 8 种气象数据作为自变量,对应的临潼水文站日径流数据作为因变量,进行多元回归模型的构建,并对临潼水文站缺失的 1986—2000 年径流数据进行数据重建。首先利用 CN05.1 气象及上游咸阳站日径流数据,共 9 维数据对临潼站径流量进行回归特征提取。抽取 1961 年、1965 年、1977 年、1981 年、1985 年、2005 年、2009 年、2013 年 8 a 的数据进行多元回归方法的构建和拟合。间隔抽取保证了整体上反映气候变化的趋势,与此同时,渭河流域 1961 年、1981 年、2005 年发生洪涝,1977 年、1985 年发生干旱,可以考虑极端气候特征,使模型可以更好地捕捉不同气候和水文条件下的特征,尽可能避免了连续年份之间径流数据的自相关性。将多个多元回归方法提取的 30 a 径流特征作为因变量输入 LSTM-BP 神经网络,剩余数据集按照 8 : 2 划分为训练集(24 a)及验证集(6 a)进行模型的构建率定工作。

2.2 结果与分析

完成对 MM-LSTM-BP 模型参数的率定后,分别使用不同回归方法进行训练,并用临潼站 2014—2019 年的日径流数据进行验证,评价指标为均方根误差(RMSE)、纳什效率系数(NSE)

2.2.1 整体回归效果

由表 1 可知,日尺度径流模拟中,训练集上的多元回归方法表现相似,其中表现最好的 GBR,其 RMSE 达到了 50.813 m³/s,NSE 也达到了 0.978,但本文构建的 MM-LSTM-BP 模型相比 GBR,RMSE 减少了 8%,NSE 提升了 0.004;验证集中,MM-LSTM-BP 模型的优势更为明显,相较于其他模型 RMSE 的提升都超过了 50%,NSE 比最好的 ARIMAX 模型也提升了 0.06,达到了 0.935。

表 1 不同模型对日尺度和月尺度临潼站径流模拟效果评价

模型	RMSE/(m ³ /s)				NSE			
	日尺度		月尺度		日尺度		月尺度	
	训练集	验证集	训练集	验证集	训练集	验证集	训练集	验证集
岭回归	91.111	114.788	71.677	109.214	0.928	0.874	0.983	0.964
套索回归	91.112	114.786	71.689	109.233	0.928	0.874	0.983	0.964
随机森林回归	62.111	122.905	40.109	110.404	0.967	0.855	0.995	0.963
GBR	50.813	117.727	49.543	109.034	0.978	0.867	0.992	0.964
多层感知回归	91.579	115.197	73.623	108.068	0.928	0.873	0.982	0.964
贝叶斯回归	91.194	114.957	72.388	110.725	0.928	0.874	0.983	0.963
ARIMAX	91.675	114.191	75.599	108.423	0.928	0.875	0.981	0.964
MM-LSTM-BP	46.743	50.248	38.870	65.135	0.982	0.935	0.994	0.960

月尺度径流模拟中,MM-LSTM-BP 模型的优势不明显,这与模型训练时所用的损失函数为日尺度有关。然而,MM-LSTM-BP 模型在训练集与验证集上的 RMSE 均展现出约 50% 的性能优势;训练集 NSE 达到 0.994,仅次于随机森林回归,验证集 NSE 亦达到 0.960。




图 5 研究区概况

Fig. 5 Overview map of research area

2.2.2 平水期及洪水期回归效果比较

为更直观评估模型回归效果,将验证期分为平水期和洪水期,分析模型在洪水过程回归中的性能与效果。由图 6 可知,平水期 MM-LSTM-BP 模型与其他回归模型相比,表现出更加稳定的特点,对洪峰模拟效果最优;平水期其他模型表现出了较明显的不确定性。洪水期 MM-LSTM-BP 模型的洪峰模拟效果更好,没有出现明显的高估或低估。在退水阶段,MM-LSTM-BP 模型也表现出更好的稳定性。由表 2 可知,MM-LSTM-BP 模型表现最为稳定,在每一次洪峰中均表现良好,而其他回归模型在每一场洪水中表现参差不齐,稳定性较差;MM-LSTM-BP 模型在洪峰回归上效果也最好,洪峰误差减少了 6% 以上。




图 6 平水期与洪水期径流模拟对比

Fig. 6 Comparison of runoff simulation between normal flow period and flood period

表 2 验证期每年最大洪峰出现日期与不同模型洪峰流量模拟相对误差

洪峰出现 日期		洪峰流量相对误差/%							
		岭回归	套索回归	随机森林回归	GBR 回归	多层感知回归	贝叶斯回归	ARIMAX	MM-LSTM-BP 模型
2014-09-17	1310	-9.4	-9.4	-20.9	-18.5	-8.4	-9.9	-11.0	-5.9
2015-07-01	550	22.8	22.8	22.1	18.6	23.9	22.6	21.2	-3.6
2016-07-15	361	-68.3	-68.2	-66.9	-63.7	-64.9	-68.0	-65.4	-57.9
2017-10-12	1550	-7.2	-7.2	-16.9	-2.8	-4.5	-7.1	-8.5	-5.9
2018-07-13	3320	-20.6	-20.6	-25.3	13.8	-18.8	-20.7	-22.2	9.2
2019-09-15	3500	-2.5	-2.4	1.0	-0.9	0.3	-2.5	-4.5	1.6

2.2.3 临潼站日径流数据重建

利用 MM-LSTM-BP 模型对临潼站缺失的 1986—2000 年的日径流数据进行数据重建,结果如图 7 所示。重建径流序列所反映的 1995—1997 年连续干旱特征,与公开新闻记录高度吻合,进一步验证了数据重建结

果的合理性与可靠性。

3 结 语

利用 MM-LSTM-BP 模型与单一多元回归模型相比,回归精度表现更佳,特别是在平水期表现出更好的稳定性;对洪水洪峰的模拟更加准确,在洪水退水阶段表现出更高的一致性;在验证集上表现良好,适用于重建临潼水文站的缺失数据,具有重要的实际应用价值。未来可以将 MM-LSTM-BP 模型应用到不同水文站点、流域,尤其是在不同气候条件下以验证模型的鲁棒性和适用范围。与此同时可以引入更多的数据源,如遥感数据、土壤湿度、植被覆盖等环境变量,以期提高预测精度,进一步提升模型的预测能力。

参考文献:

[1] 刘志雨. 我国水文监测预报预警体系建设与成就[J]. 中国防汛抗旱, 2019, 29(10): 25-29. (Liu Zhiyu. Construction and achievements of hydrological monitoring, forecasting and early warning systems in China[J]. China Flood & Drought Management, 2019, 29(10): 25-29. (in Chinese))

[2] 袁艳斌, 杨惜岁, 陈丽雅, 等. 基于多目标准则的流域站网优化[J]. 河海大学学报(自然科学版), 2019, 47(2): 102-107. (Yuan Yanbin, Yang Xisui, Chen Liya, et al. Optimization of the basin hydrologic network based on multi-objective criteria[J]. Journal of Hohai University (Natural Sciences), 2019, 47(2): 102-107. (in Chinese))

[3] 王文卓, 张建云, 陈峰, 等. 黄河源区雨季降水与汛期径流量重建及其千年尺度下的演变特征[J]. 水科学进展, 2022, 33(6): 868-880. (Wang Wenzhuo, Zhang Jianyun, Chen Feng, et al. Reconstructions of rainy season precipitation and flood season streamflow in the headwater catchment of the Yellow River and their evolution characteristics on a millennium scale[J]. Advances in Water Science, 2022, 33(6): 868-880. (in Chinese))

[4] 钟加星, 董增川, 孟金玉, 等. 基于机器学习的黄河上游梯级水库群多目标优化调度规则提取[J]. 河海大学学报(自然科学版), 2024, 52(6): 30-37. (Zhong Jiaxing, Dong Zengchuan, Meng Jinyu, et al. Extracting multi-objective optimal operation rules of cascade reservoirs in upper reaches of Yellow River based on machine learning[J]. Journal of Hohai University (Natural Sciences), 2024, 52(6): 30-37. (in Chinese))

[5] 刘娣, 孙佳倩, 余钟波. 基于机器学习模型的多层土壤湿度反演[J]. 河海大学学报(自然科学版), 2024, 52(3): 7-14. (Liu Di, Sun Jiaqian, Yu Zhongbo. Multi-layer soil moisture inversion based on machine learning models[J]. Journal of Hohai University (Natural Sciences), 2024, 52(3): 7-14. (in Chinese))

[6] 刘攀, 郑雅莲, 谢康, 等. 水文水资源领域深度学习研究进展综述[J]. 人民长江, 2021, 52(10): 76-83. (Liu Pan, Zheng Yalian, Xie Kang, et al. Review of research progress in deep learning for hydrology and water resources[J]. Yangtze River, 2021, 52(10): 76-83. (in Chinese))

[7] 邓超, 陈春宇, 尹鑫, 等. 融合数据同化与机器学习的流域径流模拟方法[J]. 水科学进展, 2023, 34(6): 839-849. (Deng Chao, Chen Chunyu, Yin Xin, et al. Catchment runoff simulation by coupling data assimilation and machine learning methods[J]. Advances in Water Science, 2023, 34(6): 839-849. (in Chinese))

[8] 田焯, 谭伟丽, 王国庆, 等. LSTM 变体模型在径流预测中的性能及其可解释性[J]. 水资源保护, 2023, 39(3): 188-194. (Tian Ye, Tan Weili, Wang Guoqing, et al. Performance of variant LSTM models in runoff prediction and their interpretability [J]. Water Resources Protection, 2023, 39(3): 188-194. (in Chinese))

[9] 苑希民, 黄玉啟, 田福昌, 等. 基于 LSTM-GM 神经网络模型的风暴潮增水预报方法[J]. 水资源保护, 2023, 39(6): 8-15. (Yuan Ximin, Huang Yuqi, Tian Fuchang, et al. Research on forecasting method of storm surge based on LSTM-GM neural network model[J]. Water Resources Protection, 2023, 39(6): 8-15. (in Chinese))

[10] 石卓, 史东华, 姚成, 等. 基于径流模数的 LSTM 模型在无资料嵌套流域的应用[J]. 河海大学学报(自然科学版), 2024, 52(3): 51-57. (Shi Zhuo, Shi Donghua, Yao Cheng, et al. Application of runoff modulus-based LSTM in ungauged nested watersheds[J]. Journal of Hohai University (Natural Sciences), 2024, 52(3): 51-57. (in Chinese))




图 7 临潼水文站径流数据重建
Fig. 7 Reconstructed runoff data of Lintong Hydrological Station

[37] Larsen F,Tran L V,van Hoang H,et al. Groundwater salinity influenced by Holocene seawater trapped in incised valleys in the Red River delta plain[J]. Nature Geoscience,2017,10(5):376-381.

[38] Yu Xiayang,Xin Pei,Pu Li. Thermal effects on flow and salinity distributions in heterogeneous coastal aquifers with fixed-flux inland boundaries[J]. Frontiers in Environmental Science,2022,10:1002587.

[39] Nguyen T T M,Yu Xiayang,Pu Li,et al. Effects of temperature on tidally influenced coastal unconfined aquifers[J]. Water Resources Research,2020,56(4):e2019WR026660.

[40] Pu Li,Xin Pei,Nguyen T T M,et al. Thermal effects on flow and salinity distributions in coastal confined aquifers[J]. Water Resources Research,2020,56(10):e2020WR027582.

(收稿日期:2024 - 10 - 14 编辑:刘晓艳)

(上接第 44 页)

[11] 李铠峰,赵超,李文戡,等. 气候变化及人类活动影响下永安溪河流水文健康响应[J]. 河海大学学报(自然科学版), 2025,53(1): 25-30. (Li Kaifeng,Zhao Chao,Li Wenyu,et al. Hydrological health response of climate change and human activities impact of the Yong' an River[J]. Journal of Hohai University (Natural Sciences),2025,53(1):25-30. (in Chinese))

[12] 徐嘉远,邹磊,夏军,等. TVGM-LSTM 耦合模型及其径流模拟效果分析[J]. 水资源保护,2023,39(6): 104-110. (Xu Jiayuan,Zou Lei,Xia Jun,et al. TVGM-LSTM coupling model and its runoff simulation effect analysis[J]. Water Resources Protection,2023,39(6):104-110. (in Chinese))

[13] 刘莉,梁霄,Wang Qunjun,等. 基于深度学习的改进 ERRIS 径流预报实时校正模型[J]. 水资源保护,2024,40(6): 155-164. (Liu Li,Liang Xiao,Wang Qunjun,et al. Improved ERRIS model for real-time correction of streamflow forecast based on deep learning[J]. Water Resources Protection,2024,40(6):155-164. (in Chinese))

[14] 鞠琴,吴金雨,王兴平,等. 机器学习算法在降水和气温多模式集成中的应用[J]. 水资源保护,2024,40(3):106-115. (Ju Qin,Wu Jinyu,Wang Xingping,et al. Application of machine learning algorithms in multimodal integration of precipitation and temperature[J]. Water Resources Protection,2024,40(3):106-115. (in Chinese))

[15] 嵇晓燕,杨凯,陈亚男,等. 基于 ARIMA 和 Prophet 的水质预测集成学习模型[J]. 水资源保护,2022,38(6):111-115. (Ji Xiaoyan,Yang Kai,Chen Ya' nan,et al. An ensemble learning model for water quality forecast based on ARIMA and Prophet [J]. Water Resources Protection,2022,38(6):111-115. (in Chinese))

[16] Sahoo B B,Jha R,Singh A,et al. Long short-term memory (LSTM) recurrent neural network for low-flow hydrological time series forecasting[J]. Acta Geophysica,2019,67(5):1471-1481.

[17] Wang Yiyang,Wang Wenchuan,Xu Dongmei,et al. A compound approach for ten-day runoff prediction by coupling wavelet denoising,attention mechanism,and LSTM based on GPU parallel acceleration technology[J]. Earth Science Informatics,2024,17(2):1281-1299.

[18] Hosseini F,Prieto C,Álvarez C. Hyperparameter optimization of regional hydrological LSTMs by random search;a case study from Basque Country,Spain[J]. Journal of Hydrology,2024,643:132003.

[19] 王维,鞠琴,王国庆,等. CN05. 1 格点降水数据在渭河流域适用性评估及应用[J]. 水文,2022,42(6):88-92. (Wang Wei,Ju Qin,Wang Guoqing,et al. Applicability assessment of CN05. 1 gridded precipitation dataset in Weihe River Basin[J]. Journal of China Hydrology,2022,42(6):88-92. (in Chinese))

[20] 吴佳,高学杰. 一套格点化的中国区域逐日观测资料及与其它资料的对比[J]. 地球物理学报,2013,56(4):1102-1111. (Wu Jia,Gao Xuejie. A gridded daily observation dataset over China region and comparison with the other datasets[J]. Chinese Journal of Geophysics,2013,56(4):1102-1111. (in Chinese))

(收稿日期:2024 - 11 - 14 编辑:刘晓艳)